

TRAITEMENT D'IMAGE

MODELES FONCTIONNELS

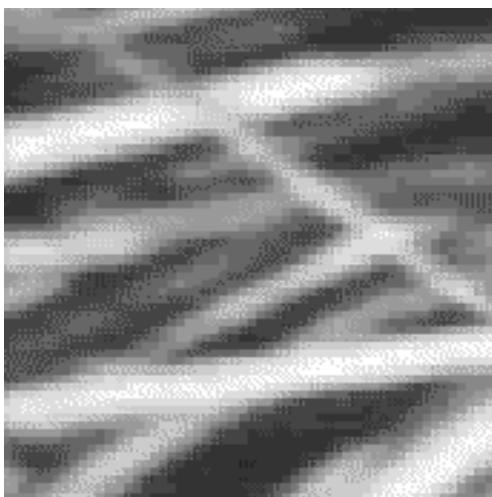
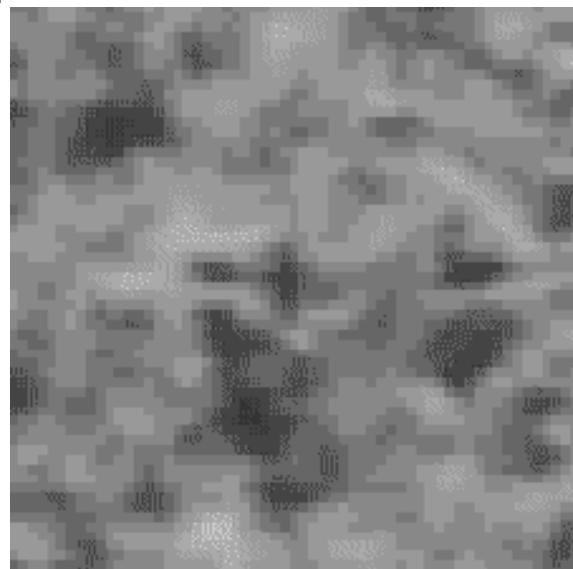
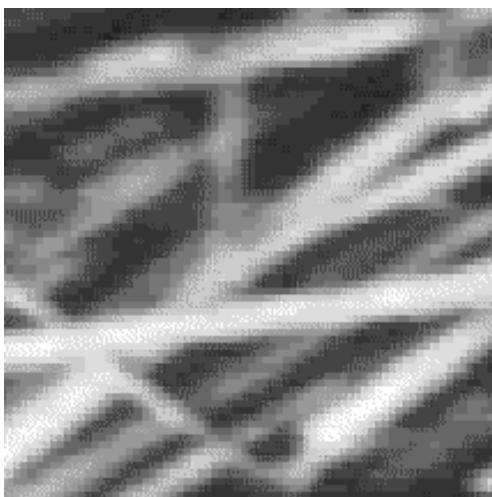
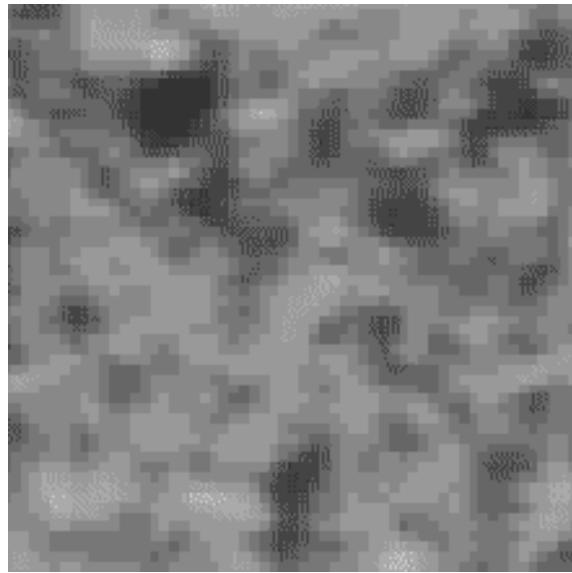
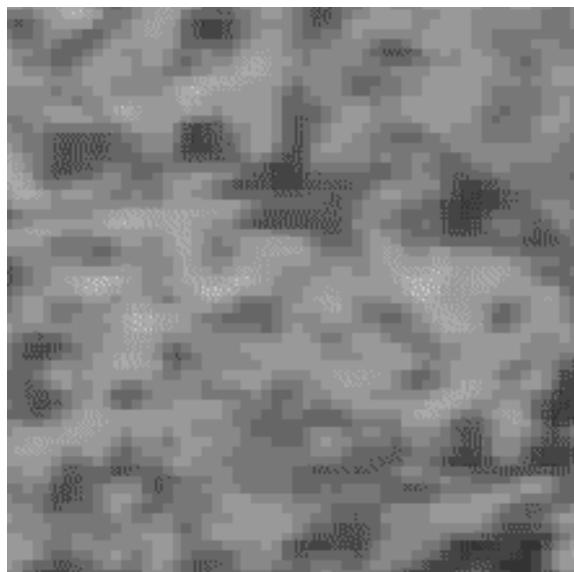
CHAMPS ALÉATOIRES

PH.BOLON

LISTIC

POLYTECH ANNECY-CHAMBÉRY

UNIVERSITÉ DE SAVOIE



1. CHAMPS ALÉATOIRES

1.1. introduction

variabilité locale des images naturelles,
textures,
bruits de capteurs

1.2. représentation

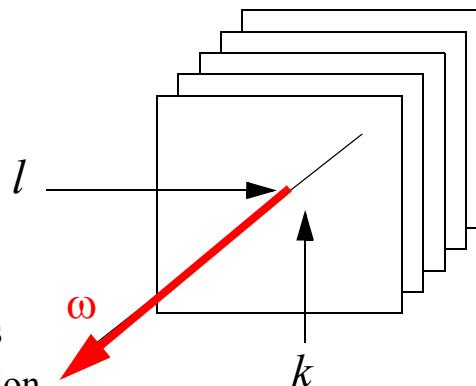
1.2.1. modèle mathématique

$$\begin{array}{ccc} X & \mathbf{R} \times \mathbf{R} \times \Omega & \longrightarrow \mathbf{R} \\ & (l, k, \omega) & X(l, k, \omega) \end{array}$$

- extension en 2D des fonctions aléatoires

ω =constante image déterministe $x(l, k)$
 (l, k) = constante variable aléatoire X

collection de réalisations particulières
 variable aléatoire dépendant de position



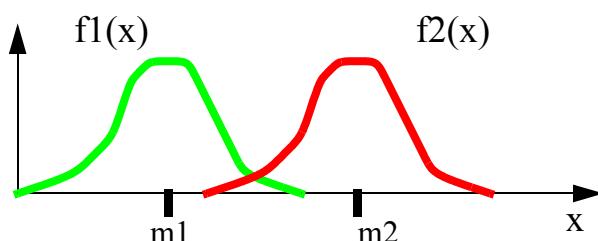
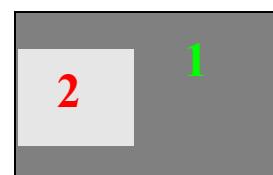
1.3. étude statistique

au premier ordre : étude de la variable $X(l, k)$

densité de probabilité : $f(x, l, k)$

fonction de répartition : $F(x, l, k)$

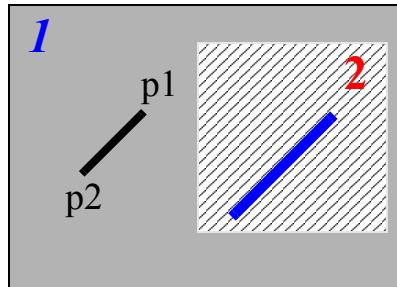
étude simplifiée : $E[X(l, k)]$



au deuxième ordre : étude des couples aléatoire $X(l_1, k_1), X(l_2, k_2)$.

densité de probabilité conjointe : $f(a, l_1, k_1, b, l_2, k_2)$

moment d'ordre 2 : $E[X(l_1, k_1)X(l_2, k_2)]$



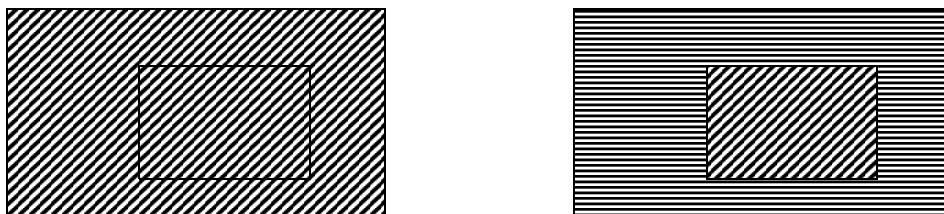
fonction de corrélation

- champs aléatoires gaussiens

1.4. champs aléatoires stationnaires

def. La loi de probabilité est invariante par translation spatiale

au premier ordre : $f(a, l, k) = f(a)$ -----> $E[X(l, k)] = \text{constante}$



au deuxième ordre : $f(\mathbf{a}, l_1, k_1, \mathbf{b}, l_2, k_2) = f(\mathbf{a}, l_1 + dl, k_1 + dk, \mathbf{b}, l_2 + dl, k_2 + dk)$

ne dépend que de la translation entre les 2 points

$$\begin{aligned} dl &= -l_2, \quad dk = -k_2 \\ f(\mathbf{a}, l_1 - l_2, k_1 - k_2, \mathbf{b}, 0, 0) \end{aligned}$$

fonction de corrélation $C(\Delta l, \Delta k)$

$$C(\Delta l, \Delta k) = E[X(l, k)X(l - \Delta l, k - \Delta k)]$$

$$E[X(l, k)X(l - \Delta l, k - \Delta k)] = \int_{R \times R} \int ab f(a, l, k, b, l - \Delta l, k - \Delta k) da db$$

1.5. modèle pour champs non stationnaires

$$X = s + B$$

s : image déterministe

B : champ aléatoire

stationnaire (au moins localement)

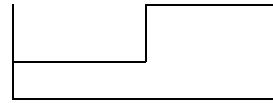
centré

éventuellement blanc

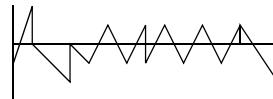
pas forcément gaussien



X



s



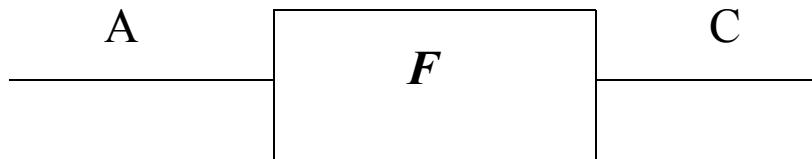
B

2. FILTRAGE LINÉAIRE DES CHAMPS ALÉATOIRES

2.1. cas continu

modèle : $A = s + B$

s : déterministe , B : aléatoire, centré,



$$\begin{aligned} C &= F(A) = F(s) + F(B) \\ &= d + N \end{aligned}$$

h : réponse impulsionnelle (PSF)

$$d = h * s$$

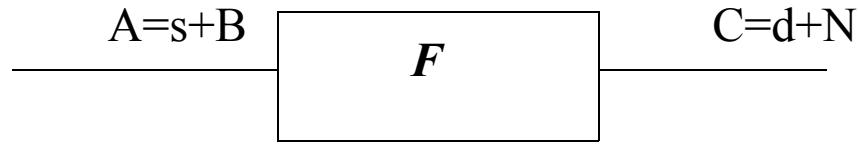
$$d(x, y) = \iint h(\alpha, \beta) s(x - \alpha, y - \beta) d\alpha d\beta$$

par transformation de Fourier

$$\tilde{d}(u, v) = \tilde{h}(u, v) \tilde{s}(u, v)$$

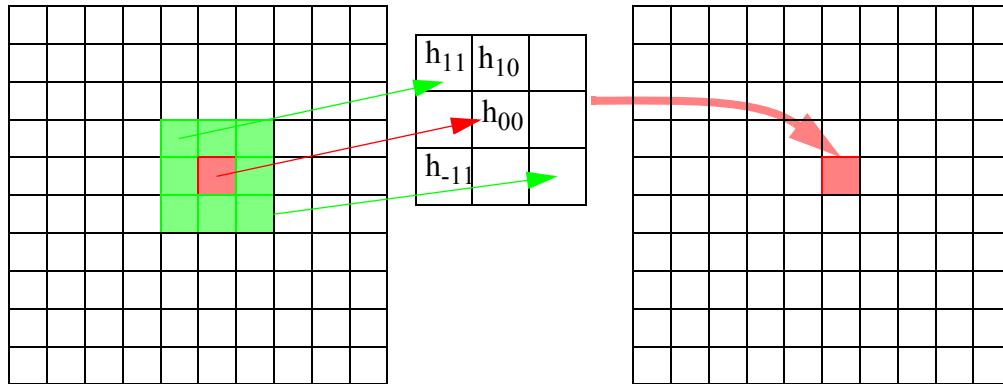
effet passe-bas, passe-haut, passe-bande, etc.

2.2. cas discret



$$d(l, k) = \sum_i \sum_j h(i, j)s(l-i, k-j)$$

$$N(l, k) = \sum_i \sum_j h(i, j)B(l-i, k-j)$$



caractérisation :

effet sur les transitions : flou, rehaussement

effet de réduction de bruit : biais, variance

$$\sum_i \sum_j h^2(i, j)$$

3. CHAMPS MARKOVIENS

modèle local décrivant les formes et la distribution des amplitudes

3.1. définitions et notations

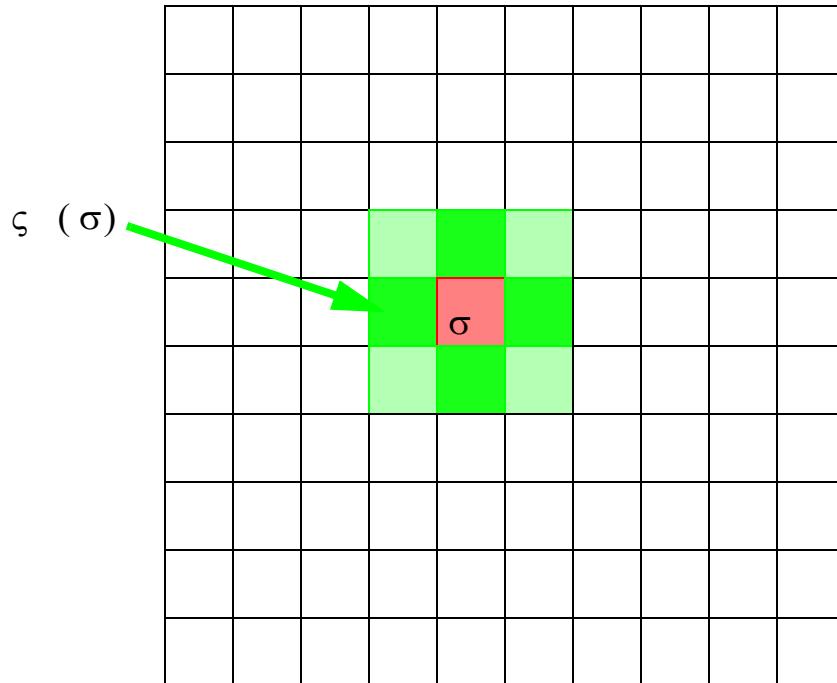
site s pixel

support spatial $S = \{s\}$

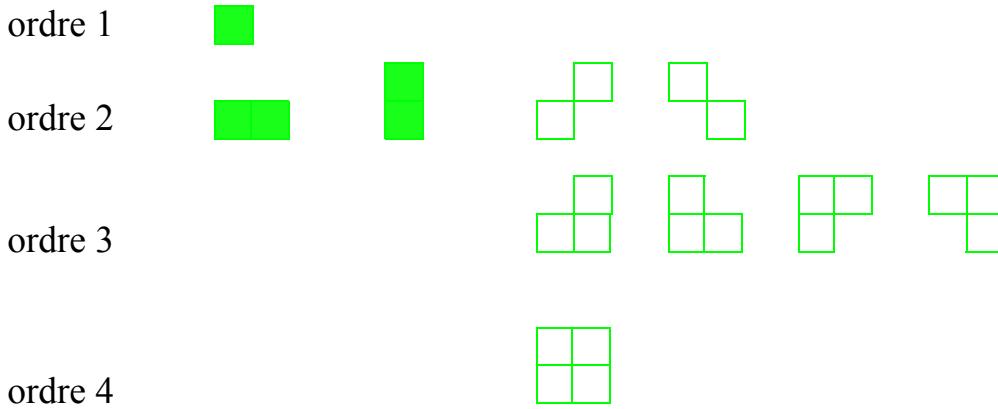
système de voisinage

$V(s)$ $t \in V(s) \Leftrightarrow s \in V(t)$

$s \notin V(s)$



clique : ensemble de sites mutuellement voisins



3.2. propriété markovienne

X : champ aléatoire défini sur S

x : réalisation particulière de X

X est un champ de Markov ssi

$$P(x) > 0$$

$$P(x_s | x_t, t \neq s) = P(x_s | x_t, t \in V(s))$$

3.3. Théorème de Hammersley-Clifford

X est un champ de Markov ssi X suit une distribution de Gibbs.

$$P(x) = \frac{1}{Z(T)} \exp\left(-\frac{U(x)}{T}\right) \quad T : \text{paramètre de Température}$$

$$Z(T) = \sum_x \exp\left(-\frac{U(x)}{T}\right) \quad \begin{array}{l} \text{constante de normalisation} \\ (\text{difficile à calculer}) \end{array}$$

$$U(x) = \sum_{c \in C} V_c(t_1, t_2, \dots) \text{ avec } (t_1, t_2, \dots) \in c$$

$V_c(t_1, t_2, \dots)$: potentiel de la clique c

conséquence

$$P(x_s = v | x_t, t \in V(s)) = \frac{\exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = v, x_t)\right)}{\sum_w \exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = w, x_t)\right)}$$

peu de termes à calculer

exemple : $V(x_a, x_b) = (x_a - x_b)^2$ favorise les intensités proches



3.4. synthèse d'un champ de Markov

choisir :

- système de voisinage
- ordre des cliques
- fonctions potentiels
- paramètre de 'température'

échantillonneur de Gibbs

étape 0 : tirer une configuration x^0 au hasard

....

étape n : ...

étape n+1 :

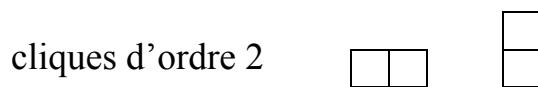
- balayer tous les pixels

calculer $P(x_s = v | x^{n-1}_t, t \in V(s))$

tirer au hasard la valeur x_s^{n+1} selon la loi ci-dessus

arrêt au bout d'un nombre déterminé d'itérations
 énergie $U(x)$ n'évolue plus

exemple : Modèle d'Ising
champ aléatoire binaire

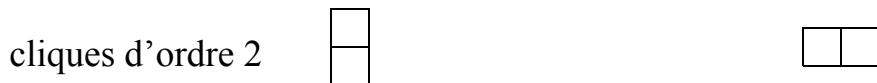


potentiels $V_c(x_s, x_t) = -b$ si $x_s = x_t$

$V_c(x_s, x_t) = +b$ sinon

exemples

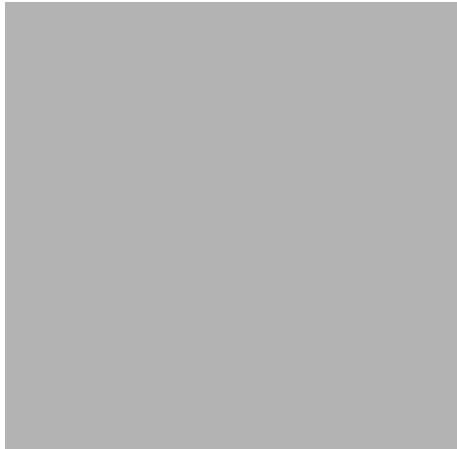
On peut introduire des contraintes de formes à l'aide des fonctions potentiels



potentiels $V_c(x_s, x_t) = -b_1$ si $x_s = x_t$ $V_c(x_s, x_t) = -b_2$

$V_c(x_s, x_t) = +b_1$ sinon $V_c(x_s, x_t) = +b_2$

exemple



initialisation



décroissance de l'énergie

T=2



image finale (35 itérations)

$$\begin{aligned} b1 &= 5 \\ b2 &= -0.1 \end{aligned}$$

3.5. application en segmentation ou restauration d'image

segmentation

Y : champ des étiquettes de région (classe), modèle markovien

X : champ des observations

problème : trouver Y sachant X

méthode MAP : chercher la configuration y maximisant $P(Y=y|X=x)$

$$Y = y$$

$$P(Y = y | X = x) = \frac{P(X = x | Y = y)P(Y = y)}{P(X = x)}$$

pour une réalisation x donnée, $P(x)=\text{constante}$

-> maximiser le numérateur

Y : champ markovien -> énergie $U_1(y)$

$X|Y$: champ markovien -> énergie $U_2(x|y)$

il faut maximiser

$$P(X = x | Y = y)P(Y = y) = \frac{\exp\left(-\frac{U_2(x|y)}{T}\right)}{K_2} \frac{\exp\left(-\frac{U_1(y)}{T}\right)}{K_1}$$

solution : minimiser l'énergie globale $U(y)=U_1(y)+U_2(x|y)$, x connu.

méthode :

- initialiser une configuration y
- synthétiser un champ de Markov par échantillonneur de Gibbs
- commencer avec T élevée, puis faire décroître T

méthode du recuit simulé

optimisation stochastique

exemple :

- T initiale = 40
- loi de décroissance : $T^{n+1}=0.98*T^n$ jusqu'à $T=1$
- 60 itérations



initialisation



décroissance de l'énergie



configuration calculée

□ possibilité de **sortir d'un minimum local** si T élevée

restauration

Y : autant d'étiquettes de classe que de niveaux de gris, modèle markovien

X : champ des observations

problème : trouver Y sachant X

méthode MAP : chercher la configuration y maximisant $P(Y=y|X=x)$

même situation que précédemment mais avec plus d'étiquettes

3.6. cas limites

- T infinie : toutes les configurations sont équiprobables

$$P(x_s = v | x_t, t \in V(s)) = \frac{\exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = v, x_t)\right)}{\sum_w \exp\left(-\frac{1}{T} \sum_{c \ni s} V_c(x_s = w, x_t)\right)}$$

- T = 0 : sélection de la (ou d'une) configuration d'énergie minimale

$$a = \arg \min \left(\sum_{c \ni s} V_c(x_s = v, x_t) \right)$$

$$P(x_s = a | x_t, t \in V(s)) = 1$$

□ quelques cas particuliers

énergie U1 : régularisation spatiale
potentiel d'une clique

$$V(y_s, y_t) = (y_s - y_t)^2$$

énergie U2 : attache aux données

$$\text{modèle de type bruit blanc } V(x_s | y_s) = (y_s - x_s)^2$$

solution : filtre moyenneur

solution itérée : filtrage linéaire gaussien

potentiels en

$$V(a, b) = |a - b|$$

solution : filtre médian

solution itérée : processus complexe => plateaux + transitions monotones

potentiels en

$$V(a, b) = |a - b|^\alpha$$

solution : filtre milieu